下载APP

06 | 如何抽取出符合真实业务场景的业务模型？

2021-04-02 高楼

高楼的性能工程实战课 进入课程 >

讲述：高楼

时长 16:57 大小 15.54M

你好，我是高楼。

我们知道，业务模型一直是性能项目中很重要的环节。在容量场景中，每个业务比例都要符合真实业务场景的比例。如果不符合，那场景的执行结果也就没有意义了。

但是，我们经常可以看到，很多性能从业人员因为对业务模型的抽取过程不够了解，或者是拿不到具体的数据，导致业务模型和生产业务场景不匹配，进而整个性能项目都变得毫无意义。

也有大量的项目，并没有拿历史业务数据做统计，直接非常笼统地拍脑袋，给出相应的业务模型，这样显然也是不合理的。可是，这种情况在金融、互联网等行业中十分常见。

当然，也有人为了让业务模型和真实业务场景尽可能匹配，会直接拿生产环境的请求进行回放。可是，即便我们拿生产环境的请求录制回放了，也不能保证业务模型和未来的业务场景一致，因为未来的业务场景会随着业务推广而变化。

所以说，我们在做场景时首先要明白，当前的场景是要模拟历史业务场景，还是未来业务场景。

如果是未来的业务场景，那就要靠业务团队给出评估，而非性能团队。不过，在当前的性能市场中，经常有企业要求性能团队给出业务模型，这显然是不理智的。首先，性能团队的业务背景不如业务团队更熟悉；其次，他们对业务市场的把握也不够专业。

其实，在真实的工作场景中，业务模型的确认从来都不应该由一个团队来做，而应该由业务团队、架构团队、开发团队、运维团队和性能团队共同确定，并最终由项目的最上层领导确认。

如果一个系统有历史业务数据，那我们获得业务模型就有背景数据了。这时候，性能团队应该从历史业务数据中抽取出各场景的业务模型。如果系统没有历史数据，那就应该像对未来业务模型评估一样，需要各团队协作给出当前的业务模型。

正是基于我们前面提到的各种问题，经常有性能从业人员问我，我们应该如何从历史业务数据中抽取出业务模型？可能你也有这样的困惑，下面我们就来详细地说一说，同时我会借助实例为你展示一个具体的过程。

大体上来说，抽取真实业务模型有两个大步骤：

1. 抽取生产业务日志。这一步可以通过很多种手段来实现。这节课我给你展示两种比较常见的手段。一种是当没有日志统计系统时，使用 awk 命令来抽取；另一种是使用 ELFK 来抽取。
2. 梳理业务逻辑。

对于第一步而言，我们抽取生产业务日志是为了得到对应的业务比例。下面我们先来看看怎么用命令抽取生产业务日志。

使用命令抽取生产业务日志

这里我以少量的 Nginx 日志举例。在 Nginx 中，日志格式通常如下所示：

```
复制代码
1 120.220.184.157 - - [26/Oct/2020:14:13:05 +0800] "GET /shopping/static/skin/gr
2 120.220.184.203 - - [26/Oct/2020:14:13:05 +0800] "GET /shopping/static/js/mani
3 120.220.184.149 - - [26/Oct/2020:14:13:05 +0800] "GET /shopping/static/js/app.
```

以上数据内容及顺序可以在 Nginx 配置文件中配置。我们的目标是抽取其中某个时间内的每秒的访问量，所以，我们只需要把对应的时间取出来统计一下即可，命令如下：

```
复制代码
1 cat 20201026141300.nginx.log|awk '{print $4}' |uniq -c
```

我们得出下面的结果：

```
复制代码
1 5 [26/Oct/2020:14:13:05
2    3 [26/Oct/2020:14:13:06
3   14 [26/Oct/2020:14:13:07
4    4 [26/Oct/2020:14:13:08
5    1 [26/Oct/2020:14:13:09
6    2 [26/Oct/2020:14:13:10
7    1 [26/Oct/2020:14:13:12
8    2 [26/Oct/2020:14:13:20
9   14 [26/Oct/2020:14:13:23
10   1 [26/Oct/2020:14:13:24
11   2 [26/Oct/2020:14:13:26
12   2 [26/Oct/2020:14:13:29
13   9 [26/Oct/2020:14:13:30
14   9 [26/Oct/2020:14:13:31
15   1 [26/Oct/2020:14:13:32
16  13 [26/Oct/2020:14:13:35
17   2 [26/Oct/2020:14:13:37
18  20 [26/Oct/2020:14:13:38
19   2 [26/Oct/2020:14:13:39
20  33 [26/Oct/2020:14:13:44
21  17 [26/Oct/2020:14:13:46
22   5 [26/Oct/2020:14:13:47
23  23 [26/Oct/2020:14:13:48
24  29 [26/Oct/2020:14:13:49
25   4 [26/Oct/2020:14:13:50
26  29 [26/Oct/2020:14:13:51
27  26 [26/Oct/2020:14:13:52
```

```
  22 [26/Oct/2020:14:13:53
  57 [26/Oct/2020:14:13:59
   1 [26/Oct/2020:14:14:02
```

这样就可以知道哪段时间里的访问量最高了。这里我们其实可以灵活运用，如果你只想取到分钟、某小时、某天都可以做相应的命令调整。例如，我们想取到分钟级，只要加上相应的截取命令就可以了，如下所示：

复制代码

```
cat 20201026141300.nginx.log|awk '{print $4}' |cut -c 2-18|uniq -c
```

对应的结果如下：

复制代码

```
 352 26/Oct/2020:14:13
   1 26/Oct/2020:14:14
```

上述结果的意思是，在我这个日志中有两分钟内的数据，第一分钟中有 352 个请求，第二分钟中只有一个请求。

如果你想请求 URL 来做统计，那么就可以修改命令：

复制代码

```
cat 20201026141300.nginx.log|awk '{print $7}' |cut -c 1-50|uniq -c
```

结果如下：

复制代码

```
.................
   1 /shopping/checkLogin
   1 /shopping/home/floor
   1 /sso/loginOut
   1 /shopping/home/navigation
   6 /shopping/home/floor
   2 /shopping/home/floorGoods
   1 /shopping/home/sysConfig
```

```
  4 /shopping/home/floorGoods
  1 /shopping/home/floor
  1 /sso/loginOut
```

此时我们取日志中的第七个数据，然后截取统计。这样我们就可以知道，每个时间段内每个请求的数量，也就可以得到相应的业务比例了。

上面这些命令你只要灵活运用，处理数据量不太大的文件是没什么问题的。

使用 ELFK 抽取生产业务日志

如果你想使用 ELFK 抽取日志，具体可以按如下步骤来做：

1. 安装 ELFK。这里的 ELFK 是指 ElasticSearch/Logstash/FileBeat/Kibana 的组合。具体安装方法可以搜索一下，网上的教程多如牛毛。
2. 配置好 ELFK 后，在 Kibana 的 Discover 界面就能看到收集的信息。注意，一条日志对应的就是一次命中。
3. 通过选择时间段就可以看到有多少请求在这个时间段内。
4. 要想得到接口请求的百分比，可以点击“Dashboard”中的“可视化”，创建一个 Lens 可视化面板，选择相应的 URL 字段就可以看到各个接口的百分比了。

总体来说，用 ELFK 抽取生产日志得到业务模型，可以分为两个阶段。

第一个阶段是统计大时间段的日志信息，然后逐渐缩小范围，比如说按年、月、天、时、分的顺序。这一步是为了将系统的峰值请求覆盖住。

第二个阶段是细化所选择的时间段。虽然我们在第一个阶段已经把时间段细化到分了，但由于我们的场景得到的结果是按秒来统计 TPS 的，所以我们要再细化到生产环境的 TPS 级别。这样就可以把生产的业务场景和测试中的场景进行对比了。

下面我通过实例给你详细讲一讲这两个阶段。

第一个阶段：统计大时间段的日志。

在查看 ELFK 中的数据时，建议你尽可能选择覆盖全部业务场景的时间段。比如说，我们要选择峰值时间段，一开始要选择时间段的范围设置大一些，这样才不会漏掉数据。然后再通过柱状图的高低做范围缩小。

通过这样的操作就可以知道生产环境中各业务接口的总体百分比了。

其实，实时将相应的日志输出到 ELFK 中，是很多企业对日志处理的常用方法。这样不仅可以实现对日志的灵活查找，也可以实现对日志的长时间存储，并且也可以做更多的后续处理，生成可视化图形之类的。在这里，我们来实际操作一下。

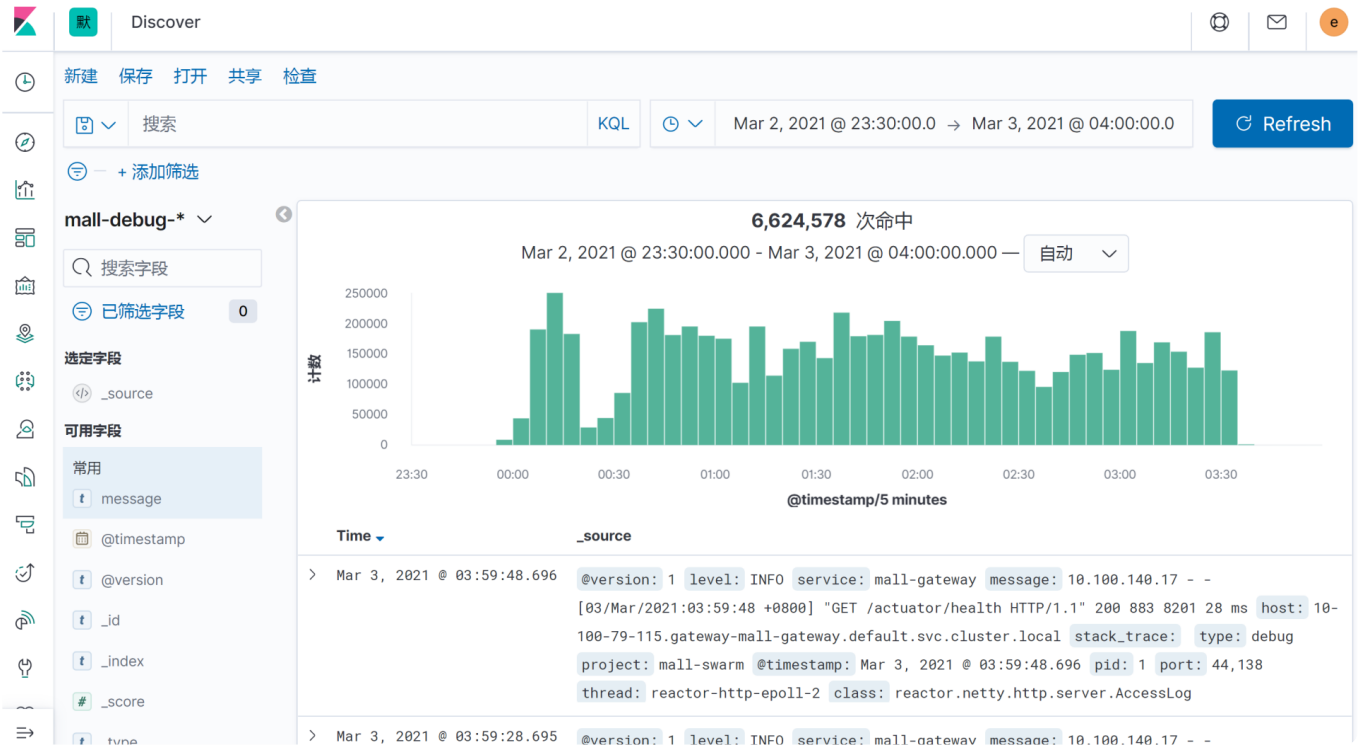

如上图所示，我们在 Kibana 中截取了一段时间的日志，这段日志总共有 6,624,578 次请求。你可以用 Kibana 直接生成下面这样的表格视图：

序号	URL
1	/mall-member/sso/login
2	/mall-portal/home/content
3	/mall-member/member/address/list
4	/mall-cart/cart/addNew
5	/mall-cart/cart/list
6	/mall-order/order/generateConfirmOrder
7	/mall-order/order/generateOrder
8	/mall-order/order/list
9	/mall-order/order/paySuccess
10	/mall-order/order/detail

这样你就可以知道哪些请求比较靠前。为什么我没有显示总数呢？因为在一段时间之内的每个请求，我们要生成相应的柱状图，如果看到它们的集中时间段是相同的，那就做一个场景即可；如果不同，则要做多个场景。下面我们来搜索一下。

/mall-member/sso/login

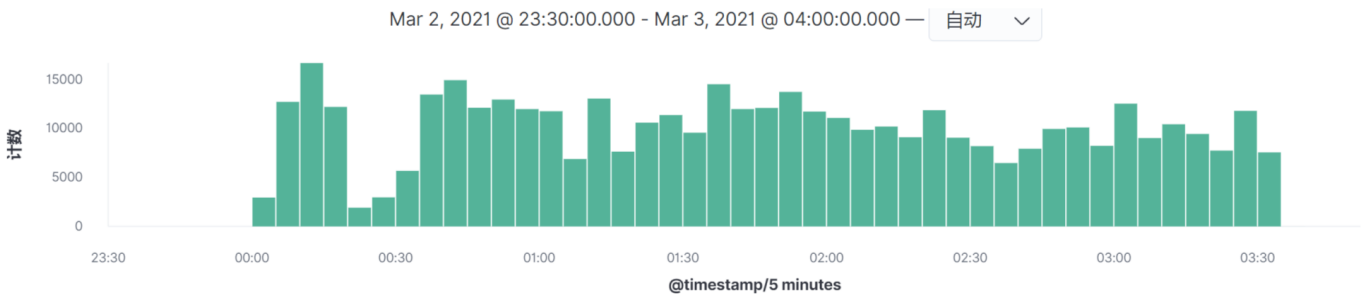

/mall-portal/home/content

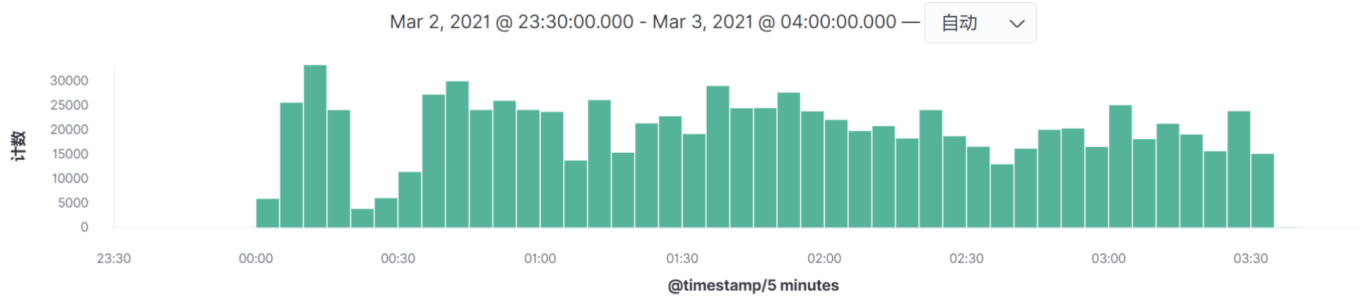

/mall-member/member/address/list

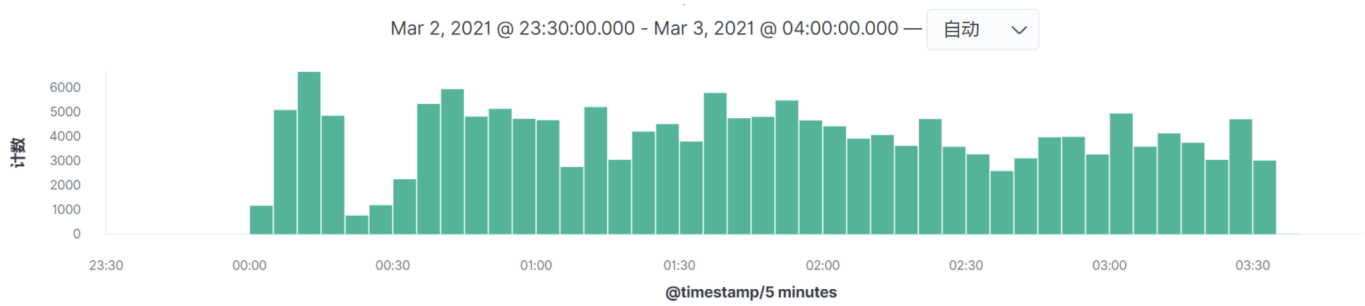

其他接口的图类似，我就不一一列了。

看图上的数据时间点，在我这个例子中，所有的请求量级的时间点都是相同的，所以我们只需要做一个场景即可全部覆盖。请你务必要注意，在你的实际项目中，并不见得会是这样。**如果出现某个请求的高并发时间点和其他的请求不在同一时间点，就一定要做多个场景来模拟，因为场景中的业务模型会发生变化。**

在我这个示例中，我们把数据量也列在表格中，同时求出比例关系，也就是拿某请求的数量除以总请求数，如下所示：

序号	URL	请求数	比例
1	/mall-member/sso/login	786171	12%
2	/mall-portal/home/content	1582439	24%
3	/mall-member/member/address/list	312741	5%
4	/mall-cart/cart/addNew	785595	12%
5	/mall-cart/cart/list	469537	7%
6	/mall-order/order/generateConfirmOrder	466036	7%
7	/mall-order/order/generateOrder	473535	7%
8	/mall-order/order/list	472840	7%
9	/mall-order/order/paySuccess	481271	7%
10	/mall-order/order/detail	794210	12%

这是在这一个时间段的业务平均比例。

通过第一阶段，我们已经可以知道哪个时间段的请求高了。但是这个时间段范围是 5 分钟，这对于任何一个系统来说，都算是比较集中的时间段了。但是我们的动作还没有结束，因为我们不仅要知道哪一段的用户操作比较集中，还要知道的是生产上能达到的 TPS 有多高。所以还需要细化，只有细化了我们才能知道具体生产的 TPS。

第二个阶段：细化时间段

通过主面图中的 Timestamp，可以看到是时间间隔是 5 分钟，我们选择最高请求的时间段，点进去。

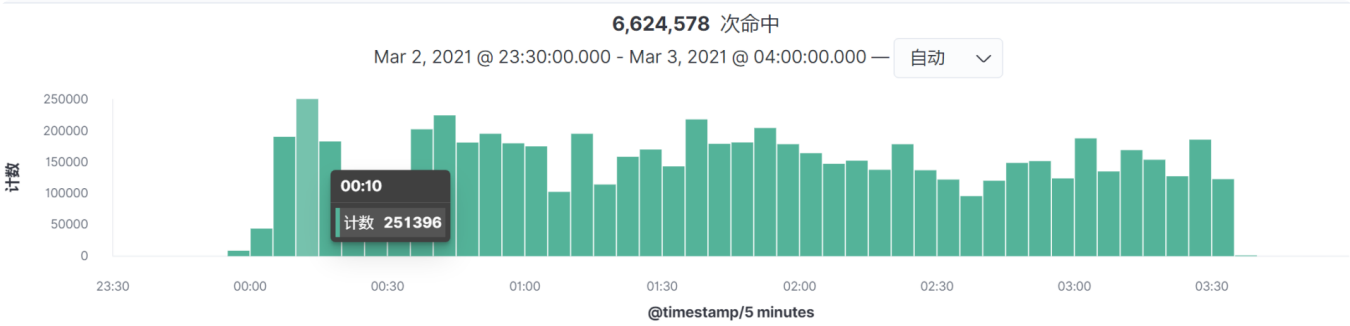

这样我们就得到时间间隔为 5 秒的图了：

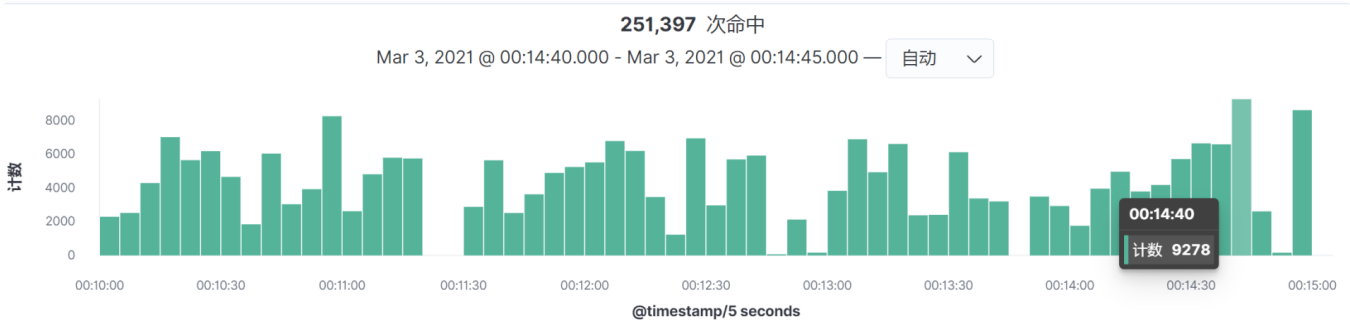

然后按命中次数来计算 TPS，就可以得到如下结果：

$$生产TPS = 9278 \div 5 = 1,855.6$$

当然了，你还可以再细化，得到毫秒级的图：

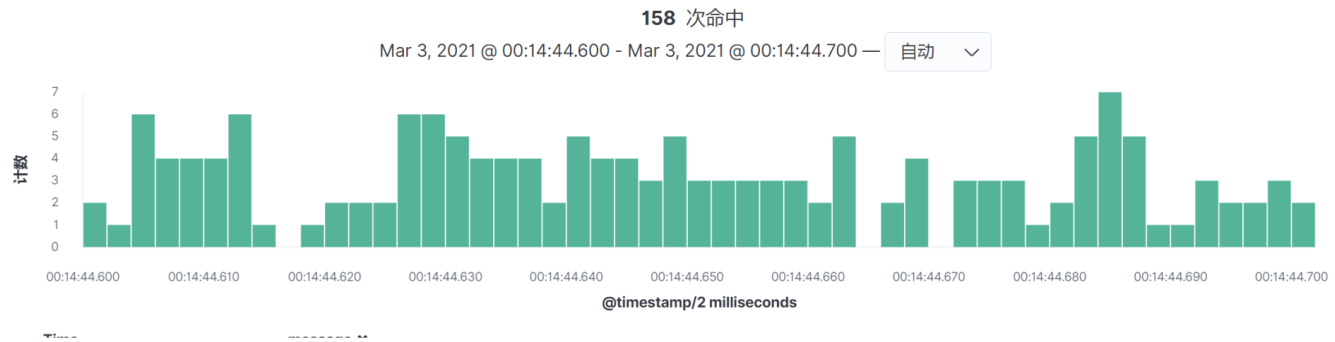

通过这种方式，我们就可以得知一个系统在生产环境中的峰值的 TPS 有多大。1855.6 这个值是我们要定的测试环境中总的 TPS。如果达不到这个值，那就要接着优化，或者增加硬件资源。

通常情况下，得到总 TPS 之后，我们要根据测试目标，分三种方式处理这个总 TPS，而这三种方式都是以**业务目标**为前提的。

1. **业务无变化，应用版本有小变化**（通常只是小的功能变化或修改 Bug）：在这种情况下，我们只要将计算出来的 TPS 做为性能场景总的 TPS 指标即可。
2. **业务无变化，应用版本有大变化**（比如说架构变更）：在这种情况下，我们只要将计算出来的 TPS 做为性能场景总的 TPS 指标即可。
3. **业务有变化，应用版本有大变化**：在这种情况下，我们要根据业务估算的增量来做相应的 TPS 增量计算。如果根据业务变化趋势预估会增加 20%，那你就可以在上面计算的总 TPS 的基础上，再加上对应的 20% 即可。

梳理业务逻辑

在上面的接口得到业务模型之后，我们就可以根据接口的量级梳理业务逻辑，以便更真实地模拟生产业务场景。其实在上面的步骤中，我们已经按顺序做了排列，你可以看一下前面的表格。

所以在这个示例中，大概有 58% 的用户会完整地走完流程。为什么是 58% 呢？因为登录的业务比例是 12%，而后面下单比例是 7%。所以是：

$$7\% \div 12\% \approx 58\%$$

整体流程说明

最后我们来梳理一下整体的流程：

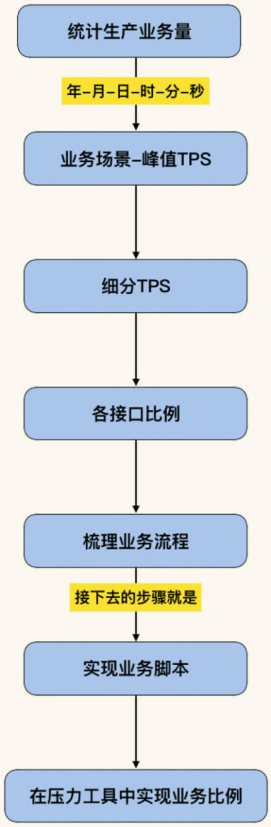

请注意，上面的业务场景在实际的项目业务统计过程中可以有多个。这个思路可以解决任何性能场景和生产场景不一致的问题。

总结

最后，我们再一起回顾下这一讲的重点内容。在业务模型抽取时我们要注意几个关键点：

1. 抽取时间：抽取时间一定要能覆盖生产系统的峰值时间点；
2. 抽取范围：抽取的范围要足够大，因为在一些场景中，即便不是峰值，但由于某个业务量较大，也会出现资源消耗大的情况；
3. 业务比例在场景中的实现：得到业务模型之后，我们在性能场景中一定要配置出对应的业务比例，不能有大的偏差。

只要做到以上几点，性能场景基本上就不会和真实业务场景有大的差异了。

课后作业

学完这节课后，请你认真思考两个问题：

1. 为什么性能场景中要模拟出真实业务比例？
2. 抽取生产数据并最终得到业务模型的步骤是什么？

欢迎你在留言区与我交流讨论。当然了，你也可以把这节课分享给你身边的朋友，他们的一些想法或许会让你有更大的收获。我们下节课见！

关于课程读者群

点击课程详情页的链接，扫描二维码，就可以加入我们这个课程的读者群哦，希望这里的交流与思维碰撞能帮助你取得更大的进步，期待你的到来～

提建议

© 版权归极客邦科技所有，未经许可不得传播售卖。 页面已增加防盗追踪，如有侵权极客邦将依法追究其法律责任。

上一篇 05 | 性能方案：你的方案是否还停留在形式上?

精选留言

写留言

由作者筛选后的优质留言将会公开显示，欢迎踊跃留言。